

شبکه‌ی LLGMN نوعی از شبکه‌های احتمالی پیش‌خور است و بر اساس مدل ترکیب توابع گوسی (Gaussian mixture model یا GMM) عمل می‌کند. در مدل GMM، تابع چگالی احتمال (PDF) یا (Probability density function) بردار مشاهدات با مجموع وزن داده شده‌ی تعداد محدودی مؤلفه‌ی گوسی بیان می‌شود. برای تخمین PDF، باید پارامترهای هر مؤلفه‌ی گوسی تخمین زده شود. در اینجا تابع توزیع $f(x)$ بردار ویژگی‌ها با K کلاس به وسیله‌ی مدل GMM به صورت رابطه‌ی (۵) بیان می‌شود (۸):

$$f(x) = \sum_{k=1}^K \sum_{m=1}^{M_k} \alpha_{k,m} g(x; \mu^{(k,m)}, \Sigma^{(k,m)}) \quad (5)$$

در این رابطه $x \in \mathbb{R}^d$ بردار ویژگی و K تعداد کلاس و M_k تعداد اجزای گوسین کلاس k بود و $\mu^{(k,m)}$ و $\Sigma^{(k,m)}$ به ترتیب بردار میانگین و ماتریس واریانس می‌باشند. در شبکه‌ی عصبی LLGMN، طبقه‌بندی بر اساس قاعده‌ی بیز انجام می‌شود و بردار مشاهده‌ی x به یکی از K کلاس نسبت داده می‌شود. قاعده‌ی بیز، کلاسی را به عنوان برچسب کلاس x انتخاب می‌کند که احتمال پسین (Posterior probability) بردار x متعلق به این کلاس از احتمال پسین سایر کلاس‌ها بیشتر باشد. احتمال پسین به صورت رابطه‌ی (۶) محاسبه می‌شود.

$$P(k|x) = \sum_{m=1}^{M_k} P(k,m|x) = \sum_{m=1}^{M_k} \frac{P(k,m)P(x|k,m)}{P(x)} \quad (6)$$

که در آن $P(k,m)$ احتمال پیشین کلاس k و جزء گوسین m ام و $P(x|k,m)$ تابع چگالی احتمال x در

از آنالیز زمان-فرکانس سیگنال HRV، بود. سیگنال HRV از آزمایش‌های با ثبت‌های کوتاه مدت در حین تست‌های اتونومیک به دست آمد.

روش‌ها

شبکه‌های عصبی احتمالی یک شبکه‌ی پیش‌سوبا چهار لایه شامل: لایه‌ی ورودی، لایه‌ی الگو، لایه‌ی جمع (Summation) و لایه‌ی خروجی می‌باشد (۹)، که بر پایه‌ی روش بیز طبق رابطه‌ی زیر عمل می‌کند:

$$g_{Bayes}(x) = \arg \max_{1 \leq j \leq K} \{\alpha_j f_j(x)\} \quad (1)$$

در این رابطه $x \in \mathbb{R}^d$ بردار ورودی، $g(x)$ کلاس x ، α_j و f_j به ترتیب احتمال پیشین و تابع چگالی احتمال کلاس j ام می‌باشند. لایه‌ی ورودی شبکه‌های عصبی احتمالی شامل d ورودی است که هر ورودی مربوط به یک ویژگی است. در لایه‌ی سوم برای تابع f_j داریم:

$$f_j(x) = \sum_{i=1}^{M_j} \beta_{i,j} p_{i,j}(x), 1 \leq j \leq K \quad (2)$$


در لایه‌ی دوم تابع کرنل گوسی قرار دارد:

$$p_{i,j}(x) = \frac{1}{(2\pi\sigma_{i,j}^2)^{d/2}} \exp\left(-\frac{\|x - c_{i,j}\|^2}{2\sigma_{i,j}^2}\right) \quad (3)$$


که M_j تعداد کرنل کلاس j ، $C_{i,j}$ و $\sigma_{i,j}$ به ترتیب بردار میانگین و ماتریس واریانس کرنل i ام کلاس j ام می‌باشند و ضریب مثبت $\beta_{i,j}$ به صورت زیر است:

$$\sum_{i=1}^{M_j} \beta_{i,j} = 1, 1 \leq j \leq K \quad (4)$$


لایه‌ی چهارم با توجه به رابطه‌ی (۱) تصمیم‌گیری می‌کند.




شکل ۱: ساختار شبکه‌ی لگاریتم ترکیب خطی توابع گوسی.



(الف)



(ب)



(ج)

شکل ۲. نمایش سیگنال Heart rate variability (HRV) در سه تست اتونومیک: (الف) کنترل تنفس، (ب) تنفس عمیق و (ج) تست برخاستن.

در نتیجه این شبکه برای پردازش الگوهای متغیر با زمان راه‌حل ویژه‌ای ندارد زیرا، (۱) حالت‌های داخلی گذشته را ذخیره نمی‌کند و (۲) الگوها را به صورت ورودی‌های مجزا در نظر می‌گیرد و پردازش می‌نماید. در این صورت نتیجه‌ی طبقه‌بندی LLGMN ضعیف خواهد بود. به همین دلیل بسیاری از محققان شبکه‌های بازگشتی را پیشنهاد می‌کنند.

کلاس k و جزء گوسین m می‌باشد. می‌توان صورت رابطه‌ی (۶) را به صورت رابطه‌ی (۷) نوشت:

$$P(k, m)P(x|k, m) = \alpha_{k, m} g(x; \mu^{(k, m)}, \Sigma^{(k, m)}) \quad (7)$$

با توجه به این که توزیع گوسین به صورت نمایی است می‌توان با لگاریتم گرفتن از رابطه‌ی (۷)، آن را به صورت خطی در آورد و به صورت زیر نوشت:

$$Y_{k, m} \triangleq w^{(k, m)T} X \quad (8)$$

به طوری که X به صورت ترکیبی غیرخطی از ورودی‌ها و $w^{(k, m)}$ به صورت ترکیبی غیرخطی از پارامترهای میانگین، ماتریس واریانس و ضرایب جزء گوسین می‌باشد. این ضرایب توسط الگوریتم آموزش تعیین می‌شوند. ساختار شبکه‌ی عصبی ترکیبی گوسین خطی با ۲ کرنل گوسی به صورت شکل ۱ می‌باشد. رابطه‌ی ورودی و خروجی این شبکه به صورت ذیل بیان می‌شود:

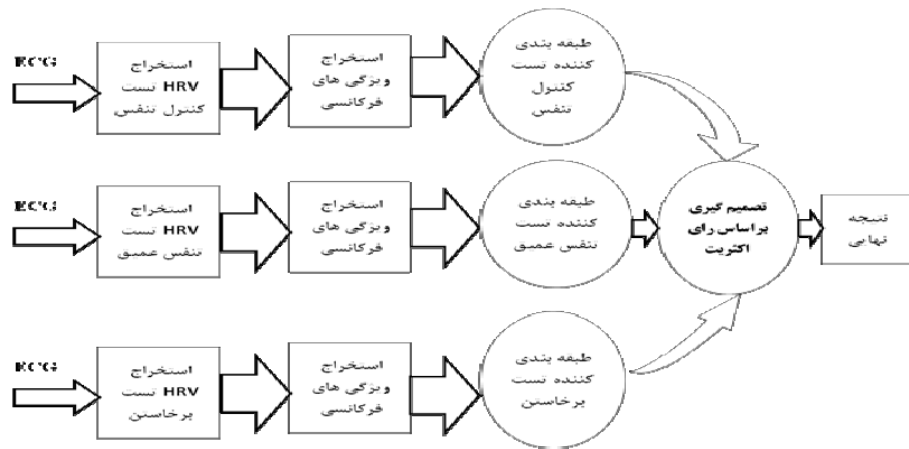
$$^{(1)}O_j = ^{(1)}I_j = X_j \quad (9)$$

$$^{(2)}I_{k, m} = \sum_{h=1}^H ^{(1)}O_h w_h^{(k, m)} \quad (10)$$

$$^{(2)}O_{k, m} = \frac{\exp[^{(2)}I_{k, m}]}{\sum_{k'=1}^K \sum_{m'=1}^{M_k} \exp[^{(2)}I_{k', m'}]} \quad (11)$$

$$Y_K = ^{(3)}I_K = \sum_{m=1}^{M_k} ^{(2)}O_{k, m} \quad (12)$$

در این شبکه‌ی الگوریتم آموزش بر پایه‌ی الگوریتم پس انتشار خطا می‌باشد. احتمال پسین هر کلاس در خروجی لایه‌ی آخر ظاهر می‌شود و در نتیجه نرون خروجی که بیشترین مقدار را داشته باشد، کلاس ورودی را معین خواهد نمود. به علت آن که این شبکه‌ی عصبی بر پایه‌ی یک مدل استاتیکی است (شکل ۳)، دینامیک سیستم را در طبقه‌بندی لحاظ نخواهد کرد.



شکل ۳. روال طبقه‌بندی سیگنال (ECG) Electrocardiogram جهت تشخیص ایسکمی با استفاده از تست‌های اتونومیک برخاستن، تنفس عمیق و کنترل تنفس.


طبقه‌بندی الگوهای زمانی داشته باشد (۱۱). در این مقاله ما از شبکه R-LLGMN جهت طبقه‌بندی سیگنال HRV برای تشخیص ایسکمی استفاده کردیم. افراد مورد بررسی در این تحقیق ۹۸ نفر بین سنین ۴۵ تا ۶۰ سال بودند (۴۸ بیمار و ۵۰ سالم). تمامی این افراد با درد و سوزش در ناحیه‌ی سینه و احساس گرفتگی در قلب به بیمارستان مراجعه کرده بودند. هیچ یک از این افراد سابقه‌ی بیماری قلبی نداشتند و با صلاح دید پزشک معالج مورد تست ورزش قرار گرفتند. به علاوه این افراد از ۴۸ ساعت قبل از تست، دارویی مصرف نکردند. آزمایشات در بیمارستان شهید آتیه‌ی تهران و با رضایت کلیه‌ی افراد مورد آزمایش، انجام شده است. قبل از تست ورزش از این افراد ثبت‌های کوتاه مدت در حین انجام تست‌های اتونومیک اخذ شد. سیگنال الکتروکاردیوگرام از بردار دوی این بیماران ثبت شد. این سیگنال ابتدا با فرکانس یک کیلو هرتز نمونه‌برداری شد و سپس با استفاده از فیلتر پایین‌گذر ۲۰۰ هرتز و فیلتر ناچ ۵۰ هرتز فیلتر شد. پس از ثبت سیگنال الکتروکاردیوگرام فاصله‌ی بین دو موج R

شبکه‌ی عصبی ترکیب خطی گوسین بازگشتی بر پایه‌ی الگوریتم مدل مارکوف مخفی (HMM یا Hidden markov model) می‌باشد (۱۱). این شبکه، مدل توسعه یافته‌ی شبکه‌ی LLGMN است که در آن از مسیرهای بازگشتی (Recurrent) استفاده شده است. مدل ترکیبی گوسین، احتمال پسین را تخمین می‌زند و هم‌زمان اتصالات بازگشتی استفاده از اطلاعات زمانی داده‌ها را امکان‌پذیر می‌سازد. شبکه‌ی LLGMN به دلیل آن که این اتصالات بازگشتی را ندارد، برای طبقه‌بندی داده‌های زمانی مناسب نمی‌باشد. در نتیجه در این شبکه تغییر آن به گونه‌ای که اثر داده‌های گذشته را نیز در نظر بگیرد، مد نظر بوده است. ضرایب شبکه‌ی R-LLGMN به ترکیب غیرخطی از پارامترهای مدل مارکوف مخفی نظیر بردار میانگین و یا ماتریس واریانس میل می‌کند. با این تفاوت که ضرایب شبکه محدودیت‌های محاسباتی مانند محدودیت‌های پارامترهای مدل آماری را ندارد. بنابراین قابلیت توصیف شبکه‌ی احتمالی بازگشتی بهتر از HMM است و انتظار می‌رود که این شبکه کارایی بهتری در



بار در دقیقه محدود کند. این کار ۲/۵ دقیقه به طول انجامید. سیگنال دو دقیقه قبل از شروع کنترل تنفس و دو دقیقه بعد از خاتمه‌ی آن نیز ثبت شد (شکل ۲ الف).
ب) آزمایش تنفس عمیق: در این آزمایش بیمار باید به مدت یک دقیقه ۶ تنفس عمیق داشته باشد، به طوری که هر دم و بازدم ۱۰ ثانیه به طول انجامد. سیگنال از دو دقیقه قبل از شروع تست تا دو دقیقه بعد از خاتمه‌ی آن ثبت شد (شکل ۲ ب).

محاسبه شد و سری زمانی به دست آمده با تابع Spline درون‌یابی شد. سپس با فرکانس ۱۰ هرتز نمونه‌برداری شد. تمام ثبت‌ها با استفاده از دستگاه Stress test از سری PC-ECG 1200 انجام شد. آزمایشات اتونومیک شامل ۳ مرحله‌ی زیر بود:



الف) آزمایش کنترل تنفس: در این آزمایش بیمار در محیطی آرام بر روی تخت دراز کشید، از وی خواسته شد که با استفاده از ساعت موجود تنفس خود را به ۱۲





(الف)





(ب)




(ج)



(د)



(و)



شکل ۴. آزمایش تنفس عمیق: سیگنال **Heart rate variability (HRV)** (الف)، نمایش زمان-فرکانس تطبیقی (ب)، توان باند **High frequency (HF)** (ج)، **Low frequency (LF)** (د) و **Very low frequency (VLF)** (و) (ستون سمت راست مربوط به فرد سالم ۴۰ و ستون سمت چپ مربوط به فرد بیمار شماره‌ی ۳۵ است)، شروع و پایان آزمایش با خط ممتد نشان داده شده است.

در تست تنفس عمیق به همراه توان باندهای VLF، LF و HF مربوط به فرد سالم شماره‌ی ۴۰ و فرد بیمار شماره‌ی ۳۵ را نشان می‌دهد.

جدول ۱. میزان دقت تشخیص ایسکمی با استفاده از RLLGNN به عنوان طبقه‌بندی‌کننده در تست‌های اتونومیک کوتاه مدت مربوط به ۹۸ نفر (۵۰ سالم و ۴۸ بیمار).

تست	حساسیت		ویژگی	
	درصد	درصد	درصد	درصد
کنترل تنفس	۷۹	۸۴	۸۲	
تنفس عمیق	۷۸	۸۲	۸۰	
برخاستن	۸۴	۸۰	۸۳	
جمع	۸۸	۸۲	۸۶	

RLLGNN: Recurrent log-linearized gaussian mixture neural network

به منظور طبقه‌بندی ویژگی‌های استخراج شده، از شبکه‌های PNN، K-nearest neighbors (KNN) و Support vector machine (SVM) و R-LLGMN استفاده کردیم. برای تعیین ایسکمی با مقایسه‌ی جواب نهایی هر یک از سه طبقه‌بندی‌کننده با توجه به رأی اکثریت، نتیجه‌گیری نهایی انجام گرفت و طبقه‌بندی در یکی از دو گروه سالم و یا بیمار ایسکمی انجام شد (شکل ۳). داده‌های آموزش به طور تصادفی از مجموعه‌ی دادگان انتخاب شدند. در جدول (۱) نتایج طبقه‌بندی بر اساس سه شاخص حساسیت (Sensitivity) و ویژگی (Specificity) و دقت (Accuracy) بیان شده است. نتایج طبقه‌بندی در دو گروه بر اساس ویژگی‌های استخراج شده از سه تست توسط RLLGNN آورده شده است. همان طور که مشاهده می‌شود

در جدول ۲ کارایی شبکه‌های عصبی احتمالی بازگشتی با روش‌های طبقه‌بندی‌کننده‌ی کلاسیک مورد ارزیابی قرار گرفته است. نتایج طبقه‌بندی بر اساس

(ج) آزمایش برخاستن: در این آزمایش بیمار بعد از دو دقیقه استراحت در حالت دراز کشیده بر روی تخت، در عرض چند ثانیه از روی تخت برخاست و بر روی زمین ایستاد. سیگنال از دو دقیقه قبل از برخاستن تا ۵ دقیقه بعد از آن ثبت شد (شکل ۲ ج). با توجه به نتیجه‌ی تست ورزش و نظر پزشک معالج افراد به دو گروه مثبت (مشکوک به ایسکمی) و منفی (سالم) تقسیم شدند. افرادی که با تست ورزش مثبت تشخیص داده شدند به آنژیوگرافی ارجاع داده شدند و نتیجه‌ی آنژیوگرافی ملاک مثبت بودن بیماری آنان بود.

یافته‌ها

در این مقاله از مؤلفه‌های فرکانسی به عنوان ویژگی استفاده شد. برای این منظور از روش طیف تطبیقی زمان-فرکانس (۱۸) سیگنال HRV استفاده کردیم. استفاده از کرنل ثابت (نامتغیر) تنها برای پردازش دسته‌ی محدودی از سیگنال‌ها کارایی دارد. از این رو محققان به طراحی الگوریتم‌های زمان-فرکانس با کرنل وابسته به سیگنال یا تحلیل زمان-فرکانس تطبیقی روی آورده‌اند که در آن‌ها تابع کرنل متناسب با سیگنال انتخاب می‌شود. از میان الگوریتم‌های وابسته به سیگنال ارائه شده در این زمینه، آن‌ها که بر مبنای بهینه‌سازی کرنل به طور شعاعی گوسی هستند، عملکرد مطلوب‌تری ارائه می‌دهند. متوسط توان در سه باند فرکانسی، فرکانس بالا یا HF (۰/۴-۰/۱۵ هرتز)، فرکانس پایین یا LF (۰/۰۵-۰/۱۵ هرتز) و فرکانس خیلی پایین یا VLF (۰/۰۳-۰/۰۵) در بازه‌های ۵ ثانیه‌ای از زمان شروع تست تا پایان هر تست اتونومیک محاسبه می‌شود و به عنوان ویژگی در نظر گرفته می‌شوند. شکل ۴ نمایش زمان-فرکانس تطبیقی

فرکانسی سیگنال HRV در حین تست‌ها و طبقه‌بندی‌کننده RLLGNN بود.

برای این منظور، در این تحقیق، از روش تحلیل زمان-فرکانس تطبیقی برای بررسی مؤلفه‌های فرکانسی سیگنال HRV در طول آزمایشات اتونومیک استفاده شد. نتایج نشان داد که تحلیل زمان-فرکانس HRV در دو گروه مورد مطالعه دارای تفاوت‌هایی است که با استخراج ویژگی‌های فرکانسی و استفاده از RLLGNN به عنوان طبقه‌بندی‌کننده می‌توان دو گروه را از هم تفکیک کرد.

تشکر و قدردانی

از مسؤولان و ریاست بیمارستان آتیه که در جمع‌آوری داده‌ها، بررسی نتایج و به ثمر رسیدن این تحقیق همکاری داشتند، صمیمانه تشکر می‌نمایم. این مقاله حاصل پایان‌نامه‌ی دوره‌ی کارشناسی ارشد در دانشگاه علم و صنعت بود.

References

1. Stamkopoulos T, Diamantaras K, Maglaveras N, Strintzis M. ECG analysis using nonlinear PCA neural networks for ischemia detection. IEEE Transactions on Signal Processing, 1998; 45(11): 3058-67.
2. Dori G, Denekamp Y, Fishman S, Rosenthal A, Lewis BS, Bitterman H. Evaluation of the phase-plane ECG as a technique for detecting acute coronary occlusion. Int J Cardiol 2002; 84(2-3): 161-70.
3. Goletsis Y, Papaloukas C, Fotiadis DI, Likas A, Michalis LK. Automated ischemic beat classification using genetic algorithms and multicriteria decision analysis. IEEE Trans Biomed Eng 2004; 51(10): 1717-25.
4. Exarchos TP, Papaloukas C, Fotiadis DI, Michalis LK. An association rule mining-based methodology for automated detection of ischemic ECG beats. IEEE Trans Biomed Eng 2006; 53(8): 1531-40.
5. Goren Y, Davrath LR, Pinhas I, Toledo E, Akselrod S. Individual time-dependent spectral

رأی اکثریت در طبقه‌بندی‌کننده‌های مختلف مقایسه شده است.

جدول ۲. کارایی RLLGNN در مقایسه با طبقه‌بندی‌کننده‌های دیگر

تست	حساسیت درصد	ویژگی درصد	دقت درصد
RLLGNN	۸۸	۸۲	۸۶
KNN	۷۶	۸۶	۸۱
PNN	۸۱	۸۴	۸۴
SVM	۷۱	۸۰	۸۰

RLLGNN: Recurrent log-linearized gaussian mixture neural network
KNN: K-nearest neighbors
PNN: Probabilistic Neural Networks
SVM: Support Vector. Machine

باتوجه به نتایج، طبقه‌بندی‌کننده RLLGNN دارای عملکرد بهتری بود.

بحث

هدف اصلی این مقاله، تشخیص زودهنگام ایسکمی به کمک تست‌های کوتاه مدت و استفاده از ویژگی‌های

- boundaries for improved accuracy in time-frequency analysis of heart rate variability. IEEE Trans Biomed Eng 2006; 53(1): 35-42.
6. Rezvani R, Erfanian A, Frootan A. Cohen class Time-frequency analysis of the heart-rate variability in patients suspected to myocardial Ischemia. Proceedings of the 13th Iranian Conference on Electrical Engineering; 2005 May 20-22. Zanzan, Iran.
7. Richard MD, Lippmann RP. Neural Network Classifiers Estimate Bayesian a posteriori Probabilities. Neural Computation 1991; 3(4): 461-83.
8. Tsuji T, Fukuda O, Ichinobe H, Kaneko M. A log-linearized Gaussian mixture network and its application to EEG pattern classification. IEEE Transactions on Systems, Man, and Cybernetics 1999; 29(1): 60-72.
9. Specht DF. Probabilistic neural networksstar, open. Neural Networks 1990; 3(1): 109-18.
10. Rutkowski L. Adaptive probabilistic neural networks for pattern classification in time-

- varying environment. IEEE Trans Neural Netw 2004; 15(4): 811-27.
- 11.** Tsuji T, Bu N, Fukuda O, Kaneko M. A recurrent log-linearized Gaussian mixture network. IEEE Trans Neural Netw 2003; 14(2): 304-16.
- 12.** Jones DL, Baraniuk RG. An adaptive optimal-kernel time-frequency representation. IEEE Transactions on Signal Processing 1995; 43(10): 2361-71.

Early Diagnosis of Myocardial Ischemia Using Heart-Rate Variability and Recurrent Probabilistic Neural Network

Majid Vafaezadeh¹, Abbas Erfanian Omidvar PhD², Abbas Forotan PhD³

Abstract

Background: Myocardial ischemia is caused by a lack of sufficient blood flow to the contractile cells and may lead to myocardial infarction with its severe sequel of heart failure, arrhythmias, and death. Therefore, its early diagnosis and treatment is of great importance. During past several years, several strategies have been proposed for automatic detection of ischemic cardiac beats using the ST-T complex of the electrocardiogram (ECG) which is recorded during long-term Holter monitoring. However, automatic detection of ischemic subjects using short-term analysis of the ECG is an open problem. In this paper, we presented a new method for automated detection of ischemic patients.

Methods: The study was conducted based on short-term analysis of the ECG, time-frequency analysis of heart-rate variability (HRV) and recurrent log linearized Gaussian mixture neural network (RLLGMN) as the classifier. For this purpose the feature vector was extracted from the energy of HRV was obtained from 98 subjects (50 healthy and 48 patients) at different frequency bands during different autonomic tests (i.e. controlled normal breathing, controlled deep breathing and active transition tests) and classified using a probabilistic neural network.

Findings: The results showed that a correct classification rate of 82% for the healthy subjects and 86% for the ischemic subjects was achieved using the proposed method.

Conclusion: The results indicated that HRV signals and recurrent probabilistic neural network can be used as a noninvasive method for identifying ischemia. The proposed method is simple, fast and noninvasive, and does not require the long-term recording of ECG signals as well as exercise treadmill test.

Keywords: ST-T complex, Wavelet analysis, Myocardial ischemia, Heart-rate variability

¹ MSc Student, Iran Neural Technology Research Center, Department of Biomedical Engineering, School of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran

² Associate Professor, Iran Neural Technology Research Center, Department of Biomedical Engineering, School of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran

³ Assistant Professor, Department of Physiology, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran

Corresponding Author: Abbas Erfanian Omidvar PhD, Email: erfanian@iust.ac.ir